人工智能在农业风险管理中的应用研究综述

桂泽春，赵思健[*]

（中国农业科学院农业信息研究所，北京 100081）

摘　要： 农业是关系国计民生的基础产业，但同时又是弱质产业，传统农业风险管理研究方法中存在非线性信息挖掘不足、精确度不高和鲁棒性差等问题。人工智能（Artificial Intelligence，AI）拥有基于大数据的强非线性拟合、端到端建模和特征自学习等强大功能可很好地解决上述问题。本文首先分析了AI在农业脆弱性评估、农业风险预测，以及农业损害评估三大方面的研究进展，得出如下结论：1. AI在农业脆弱性评估中的特征重要性评估缺乏科学有效的验证指标，且应用方式导致无法比较多个模型之间的优劣，建议采用主客观法进行评价；2. 在风险预测中，发现随着预测时间的增加，机器学习模型的预测能力往往会下降，过拟合问题是风险预测中的常见问题，且目前研究针对图数据空间信息的挖掘还较少；3. 农业生产环境复杂，应用场景多变是影响损害评估准确性的重要因素，提升深度学习模型的特征提取能力和鲁棒性是未来技术发展需要克服的重点和难点问题。然后，针对AI应用过程中存在的性能提升问题和小样本问题提出了相应的解决方案。对于性能提升问题，根据使用者对人工智能的熟悉程度，可分别采用多种模型比较法、模型组合法和神经网络结构优化法以提升模型的性能表现；对于小样本的问题，往往可以将数据增强、生成对抗网络和迁移学习相结合，以增强模型的鲁棒性和提高模型识别的准确性。最后，对AI在农业风险管理中的应用进行了展望。未来可以考虑将人工智能引入农业脆弱性曲线的构建；针对农业产业链的上下游关系和与农业相关的行业关系，更多地应用图神经网络对农业价格风险预测进一步深入研究；损害评估建模过程中可以更多地引入评估目标相关领域的专业知识以增强对目标的特征学习，对小样本数据进行增广也是未来研究的重点内容。

关键词： 农业风险管理；人工智能；脆弱性评估；风险预测；损害评估

中图分类号： F302; TP301　　**文献标志码：** A　　**文章编号：** SA202211004

引用格式：桂泽春, 赵思健. 人工智能在农业风险管理中的应用研究综述[J]. 智慧农业(中英文), 2023, 5(1): 82-98.

GUI Zechun, ZHAO Sijian. Research application of artificial intelligence in agricultural risk management: A review[J]. Smart Agriculture, 2023, 5(1): 82-98.

1　引　言

中国是农业大国，农业是关系国民粮食安全的基础产业，但同时农业又是弱质性产业，相比于其他产业更容易遭受各类风险的冲击[1-3]。由于自然环境的不可控性、动植物生长过程中的不确定性和市场经济体制下成本和出售价格的波动性等一系列风险因子，导致农业是高风险产业。因此，对农业实施风险管理，降低粮食安全风险和减少农民损失，显得十分迫切且重要[4]。农业产业的本质是经济再生产与自然再生产相交织的过程，该本质特点既决定了农业的弱质性，也决定了农业风险类别的多样性。农业风险大体上划分为4大类：自然生产风险、市场风险、个人风险以及政策监管风险[5]。从风险严重性程度上看，农业风险主要来源于自然生产风险以及市场风险。

根据风险事件发生时间前后，可以将农业风险

收稿日期：2022-11-11

基金项目：中国农业科学院农业信息研究所科技创新工程项目（CAAS-ASTIP-2016-AII）；教育部人文社会科学重点研究基地重大项目（17JJD910002）；国家自然科学基金面上项目（41471426）

作者简介：桂泽春，硕士研究生，研究方向为农业风险管理。E-mail：guizechun2022@163.com

[*]通信作者：赵思健，博士，研究员，研究方向为农业风险管理及保险。E-mail：zhaosijian@caas.cn

管理周期分为三个阶段：事前预防准备阶段、事中反应阶段和事后恢复阶段[6,7]（如图1所示）。在各环节中，以往常常采用量化指标赋权打分、简单回归线性拟合数据和基于人工手动提取特征等方法对实际问题进行建模，不仅无法挖掘出数据中的非线性信息，还存在着精确度不足和鲁棒性差的问题。以机器学习和深度学习为代表的人工智能（Artificial Intelligence，AI）在农业风险管理周期中的脆弱性评估、风险预测和损害评估等三大方面做了较多研究工作，很好地解决了以往传统技术方法中存在的问题。

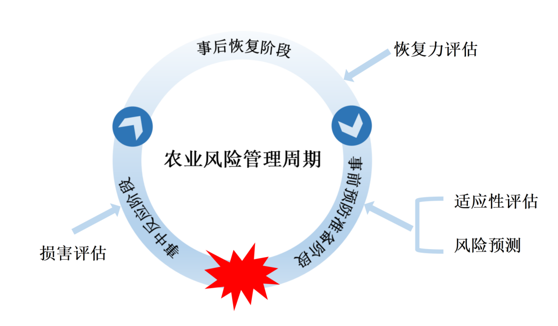


图1 农业风险管理周期及相应分析评估

Fig. 1 Agricultural risk management cycle and corresponding analysis and evaluation

本文从农业风险管理的三大方面——农业脆弱性评估、农业风险预测和农业损害评估出发，分析当前AI在该领域的应用进展，总结当前研究发展现状，提出当前存在的问题和解决方法，并展望AI在农业风险管理中未来的技术研究和发展方向，旨在为推动AI更好地服务于农业风险管理提供参考。

2 在农业脆弱性评估中的应用研究

从狭义上讲，脆弱性表示的是承灾体在灾害中遭受致灾因子打击能力的一种度量，只包含适应性。而从广义上讲，脆弱性是一个综合概念，由风险性、适应性和恢复力等相关概念组成[8-10]。本文讨论的是广义上脆弱性范畴。

目前国内外使用AI对农业进行脆弱性评估的主要方法是构建可以反映农业脆弱性的量化指标评估体系，再采用AI对量化指标进行赋权打分加总，最终得到评估目标的脆弱性分数或者等级[8, 11, 12]（如图2所示）。对农业进行脆弱性评估可以为增强农业风险管理能力和进行针对性治理提供政策依据。在农业脆弱性的多元量化评估体系中，输入变量的选择非常重要。农业脆弱性具有自然属性和社会经济性，即脆弱性不仅与当地气温、降水和区域地形有关，还与当地人均国内生产总值、人口密度和科学技术等因素有关[13]。然而当前对于不同量化评价指标的权重赋值并没有普遍有效的评价标准。本节重点介绍在农业脆弱性评估中可以对变量特征重要性进行权重赋值的3类AI方法，包括模型自身输出法、相关系数法、神经网络法及其具体应用。

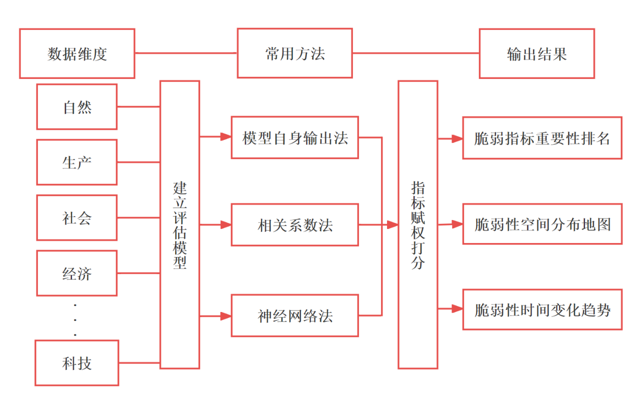


图2 基于人工智能的农业脆弱性评估过程

Fig. 2 Agricultural vulnerability assessment process based on artificial intelligence (AI)

2.1 模型自身输出法及其应用

如随机森林（Random Forest，RF）和极限梯度提升（eXtreme Gradient Boosting，XGBoost）这种以决策树为基础的数据集成学习算法，算法本身就可以通过学习输入的农业脆弱性指标和目标值之间的关系直接对特征重要性进行打分[14, 15]，这类计算权重的方法称为模型自身输出法。Li等[16]基于曝光-敏感-适应能力（Exposure-Sensitivity-Adaptive capacity，ESA）框架创建暴雨灾害脆弱性指标体系，将降水、经济、社会发展数据作为输入，采用RF算法对时空特征和特征重要性进行评估和分析。Deng等[17]使用RF算法量化主要影响因子对农业干旱灾害的影响，筛选出农作物总播种面积、降水量、有效灌溉面积、国内专利申请授权、地区生产总值是影响农业干旱灾害的前5位主导因素，国内专利申请授权指标在一定程度上反映了当地的科学技术水平，而科学技术也是反映抗旱能力的重

要指标。Kinnunen等[18]采用XGBoost算法来衡量人为因素对作物产量减产风险的影响，发现人为因素解释了整个时期40%～60%的产量损失变化。孙鹏等[19]选取与旱灾脆弱性呈现正相关和负相关的16个指标，以脆弱性指标作为输入值和受灾率指标作为目标值，通过RF算法评估指标的重要性从而对各项指标进行客观赋权，再使用加权综合评分法来确定旱灾脆弱性。

采用模型输出法计算指标权重易于实现，且工程实现成熟，建模后可直接输出指标重要性柱状图，但无法衡量输入指标对目标值的正负向影响，可进一步通过分析输入变量与目标值之间的逻辑关系进行确定。

2.2 相关系数法及其应用

线性回归和逻辑回归（Logistic Regression，LR）等机器学习模型，可以使用建模后输入变量与目标值之间的相关系数来衡量农业脆弱性指标对目标值的影响程度和效果，这类计算权重的方法称为相关系数法。Samuel等[20]采用差分模型和逐步多元线性回归来量化气候适应技术对干旱期间农户收入的影响，发现农场规模、牲畜拥有量、气候适应技术和农业投资是影响农场收入的决定性因素。刘伟等[21]选择多元线性回归模型分析估计农户暴露度、敏感性、适应能力和生计脆弱性的影响因素。Melketo等[22]采用主成分分析法和一般线性回归模型确定牧区家庭对粮食不安全恢复力的决定因素，发现家庭规模、年龄、财富、灌溉条件、水土保持技术的利用等因素显著解释了家庭恢复力生产状况的变化。和月月和周常春[23]采用熵值法评价农户的生计脆弱性，并利用多元线性回归模型对生计脆弱性的影响因素进行实证分析。Saha和Pal[24]使用逻辑回归和模糊逻辑方法，根据7个参数实现对湿地的物理脆弱性评估。

相关系数法通过对输入值和目标值之间进行建模得到二者之间的关系，其中的线性回归算法的权重可以清楚直接地度量输入特征对目标值的影响程度，且可以通过相关系数的正负号来判断输入与目标之间的正负相关关系，但缺点是由于线性模型较为简单，只能挖掘线性关系，当建模对象较为复杂或非线性时，其本身的拟合效果和准确度表现并不是太好。

2.3 神经网络法及其应用

采用以BP网络（Back Propagation Neural Network，BPNN）为代表的人工神经网络（Artificial Neural Network，ANN）来建立输入变量和评价对象脆弱性之间的关系，从而给出相应指标的量化权重，这类计算权重的方法称为神经网络法。Roy等[25]基于18个干旱脆弱性因子，使用ANN和最大熵模型评估了干旱脆弱性对印度粮食安全的影响。谢家智等[12]从自然、经济、社会、科技四个维度出发，构建30个基础指标进行定量量化，通过对各个神经元之间的权值加以分析得到基础指标的决策权重，运用BPNN对农业旱灾脆弱性进行了综合评价分析。张帅等[26]从敏感性指数和应对能力指数出发，基于BPNN对土地生态系统脆弱性进行综合评价和时空演化分析。Saha等[27]采用50个干旱脆弱性决定变量，将干旱分为水文、农业、气象和社会经济四大类，再采用深度学习神经网络、ANN和多任务高斯过程来绘制干旱脆弱性地图。苏芳等[28]从健康、环境、金融、社会、信息等五大风险维度出发，使用BPNN对农户的生计风险进行定量化测度。

采用神经网络法进行权重赋值主要是利用神经网络模型强大的非线性拟合能力对输入和输出之间进行建模，尤其适合高维复杂非线性的拟合建模任务，其缺点是存在“黑箱”问题，可解释性不强。

2.4 对脆弱性评估方法的评价

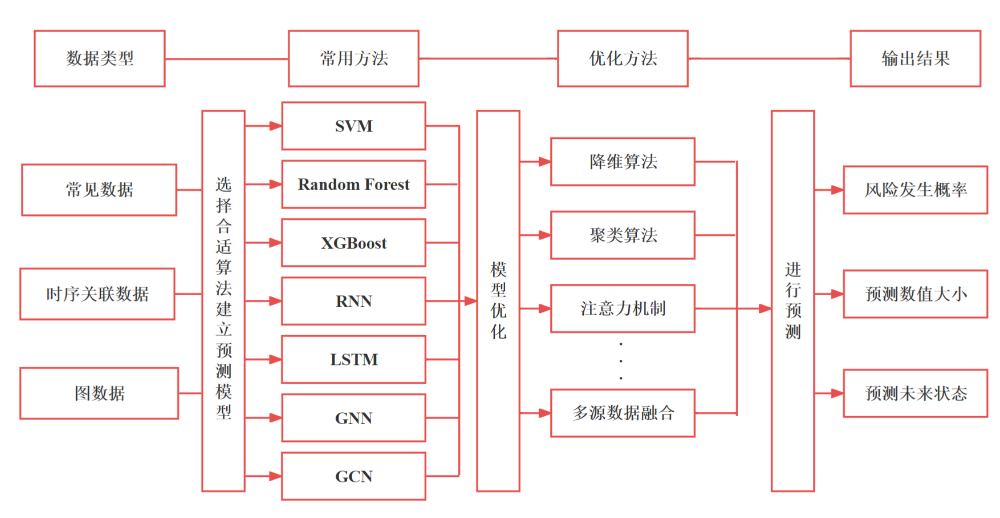
目前在对于农业脆弱性的多维变量评估中，仍然没有量化科学的指标证明一种AI算法要优于其他AI算法，究其原因是由AI在农业脆弱性评价中的应用方法所决定的。以往AI在其他领域中的应用是以回归和分类为主，属于监督学习，有明确的评价标准，如均方根二次误差（Root Mean Square Error，RMSE）、均方误差（Mean Squared Error，MSE）和ROC曲线下与坐标轴围成的面积（Area Under Curve，AUC）等，模型表现得好坏与否可以直接通过标价标准的大小表现，属于端到端建

模。而AI在农业脆弱性中的应用同样要进行回归或者分类，建立输入变量和输出变量之间的关系，但区别之处在于，对脆弱性的评估只要得到输入和输出之间的映射关系即输入变量权重大小，并没有对应的指标去对变量权重本身进行评价，从而无法证明模型之间的优劣。不过，在一些文献对比中发现RF算法要比其他算法表现好得多，其原因在于RF算法对噪声相对不敏感，引入了随机性从而不容易过拟合，并且可以有效挖掘输入变量与输出变量之间的非线性关系，即强非线性拟合[29-31]。

在今后的应用研究中，作者认为可以将RF算法作为一种基准模型与其他权重评价方法进行结果对比，再引入专家知识对权重进行二次主观筛选或权重调整，从而实现对农业脆弱性的主客观综合评价，提高评估的准确性。

3 在农业风险预测中的应用研究

农业风险主要来源于自然生产风险和市场风险，进行风险预测有助于人们提前采取恰当的行动和准备方案去应对风险因子以减少损失和降低风险。目前AI在风险预测中的应用主要以回归和分类算法为主，聚类和降维算法常作为数据预处理方法参与风险预测。AI通过学习输入变量到输出变量之间的映射关系，从而实现对非线性信息的拟合和对特征的学习，所以输入的农业风险变量本身的数据类型对使用AI进行风险预测有着重要影响作用[32]。本节从常见数据、时序关联数据、图数据3种输入数据类型出发，介绍特定数据所适用的AI算法及其在农业风险预测中的应用（如图3所示），为之后的AI应用提供参考。



注：支持向量机（Support Vector Machine，SVM）、循环神经网络（Recurrent Nerual Network，RNN）、长短期记忆网络（Long Short-Term Memory，LSTM）、图神经网络（Graph Nerual Network，GNN）、图卷积网络（Graph Convolutional Network，GCN）

图3 基于AI的农业风险预测过程

Fig. 3 Agricultural risk prediction process based on AI

3.1 常见数据及其适用算法应用

常见数据类型主要有两类，分别是连续型数据和离散型数据。连续型数据属于定量数据，具有连续属性，在定义域上有无穷多个可能的取值；离散型数据属于定性数据，具有离散属性，在定义域上具有有限个可能的取值。输入数据类型为常见数据的风险预测是农业风险预测的主要组成部分，同时其适用的预测算法也是多种多样的，其中最常用的模型是RF、神经网络、支持向量机（Support Vector Machine，SVM）、线性回归和梯度提升树，大多数研究通过对比使用各种机器学习模型来筛选出预测性能最好的模型[33-37]。应用领域主要包括对农作物产量的预测、自然风险的预测和农产品市场风险预测等，应用方法以回归和分类为主，聚类和降维算法常作为数据预处理方法参与到风险预测中。

3.1.1 自然风险预测

自然风险是对农作物及牲畜生长造成破坏的主要因素。自然风险主要为水旱风险，而水文系统是

复杂的，其特点是过程和事件的动态取决于各种直接因素（如气象和环境）和间接因素（如人类作用）之间的相互关联[38]。对自然风险的预测有利于保障农民收入，保护国家粮食安全。

（1）干旱风险预测。使用遥感数据进行农业干旱特征描述和预测有助于提供大范围地理区域干旱状况的概况[39, 40]。Prodhan等[41]通过多种遥感数据，如空间分辨率为500 m的MODIS（Moderate Resolution Imaging Spectroradiometer，中分辨率成像光谱仪）植被指数和空间分辨率为1 km的地表温度等，采用深度学习方法来对干旱灾害进行监测，其建模估计的年际变化土壤水分亏缺指数与原始的标准化降水蒸散指数几乎相似，验证了该方法在干旱检测中的适用性。然而针对干旱灾害的短期预测问题仍然具有挑战性，可以通过引入实时数据对预测结果进行修正。Park等[42]利用从MODIS获取的空间分辨率为5 km的地表温度和归一化植被指数等遥感数据，使用实时多变量马登-朱利安振荡（Madden-Julian Oscillation，MJO）指数输入RF模型中进行预测，实验结果验证加入MJO变量的RF预测模型（平均R^2为0.7）要优于原始RF模型（平均R^2为0.4）。

除了遥感数据之外，通过构建可以描述干旱的降水指数也可以增强模型的数据挖掘能力。Zhang等[43]基于机器学习和深度学习模型，发现降水和土壤水分对干旱贡献较大，其中构建的归一化差别水分指数相对重要性高达50%。另外，将新的预测方法融合到机器学习模型中可以提高模型的学习能力。Li等[44]将前期海面温度波动模式与机器学习技术结合，验证了其能有效预测干旱事件的时空演变。张建海等[45]将差分整合移动平均自回归（Autoregressive Integrated Moving Average，ARIMA）模型与长短期记忆网络（Long Short-Term Memory，LSTM）相结合进行干旱预测，其预测结果的RMSE值低于只使用ARIMA算法进行预测，验证了ARIMA和LSTM的复合模型要优于单一ARIMA模型。

利用遥感技术可以更加迅速全面地监测环境信息，构建有效的降水指标可以更加准确地评估农作物干旱程度，两者都为使用AI建模提供了有效的输入信息量。

（2）洪涝风险预测。洪水灾害在全球范围内造成巨大的经济、社会和环境破坏，因此对水灾的预测可以降低自然风险对人类社会的影响[46]。对比多种AI模型以及使用混合模型进行建模有助于提升模型预测表现。Venkatesan和Mahindrakar[47]对比多种机器学习模型对短期洪水预测，采用纳什萨克利夫效率、百分比偏差、RMSE、R^2四个指标作为模型评价指标，最终验证了极限梯度提升算法在预测精度上优于RF和SVM。Mirzaei等[48]对比使用极端梯度提升算法和RF对洪水敏感性进行评估，AUC分别为0.985和0.980，同时采用RF算法评估变量的重要性，发现距河流的距离对洪水敏感性有重要影响。Tabbussum和Dar[49]利用所有可用的训练算法对ANN、模糊逻辑、自适应神经模糊推理系统算法进行优化，开发出9种洪水预测模型，其中采用混合训练算法建立的自适应神经模糊推理系统性能指标最佳，R^2为97.066%，MSE为0.00034，RMSE为0.018。

使用AI预测未来洪水预期状态及数值发现，随着预测时间的增加，机器学习模型的预测能力往往会下降。Zhang等[50]分别使用四种AI算法——决策树、多层感知机、RF、SVM对陕西省三个典型流域进行逐小时洪水预报，随着预测提前期的增加，不同模型的性能差异很大，SVM模型整体稳定，对洪水预测具有明显优势，RF和决策树的预测性能随着提前期的增加缓慢下降，而多层感知机的性能随着提前期的增加迅速下降，稳定性较差。

由于不同模型及算法有其各自的数据挖掘能力及适用范围，将应用领域的专业知识或者模型与AI结合到一起，使用混合模型对风险进行预测和建模会有更好的效果。

3.1.2 生产风险预测

在农业生产经营中，牲畜容易受自身因素以及外界环境的影响导致个体患病，及时评估牲畜个体的身体条件、患病情况以及生产环境状态对于农业生产经营的持续健康发展意义重大。随着物联网技术和传感器技术的发展，当前对生产风险的预测常常会融合多源数据进行建模，从而实现对预测目标更加准确的状态预测。Ebrahimi等[51]将通过电子

在线检测监测系统所获得的奶牛的一些生理指标如乳糖浓度、电导率、蛋白质浓度等指标输入多种机器学习模型中实现对奶牛患乳腺炎的预测，其中梯度提升树模型预测效果最好，准确率达84.9%。Teixeira等[52]使用LSTM模型对可穿戴传感器设备所获取的数据进行建模，实现对牛疾病的预测，准确性最高可达98%。

除了通过现代精密技术和仪器对生产目标进行客观描述，还可以通过人工检查来进一步为生产风险预测提供更多的信息量。Casella等[53]基于机器自动和人工收集到的数据，使用成本优化价值法对特征进行选择，然后使用机器学习算法建模预测小奶牛呼吸系统疾病，结果表明在进行疾病诊断前5天对病牛的分类正确率达97%。考虑到在数据处理收集过程中会出现小样本问题，针对收集到的数据还可以使用生产对抗网络来扩展数据集从而增加数据量。Ahmed等[54]使用物联网穿戴设备来识别家鸡的疾病和运动状态，通过生产对抗网络增加数据量，然后使用机器学习算法实现对病鸡的分类建模，实验结果表明其所提出的家禽疾病检测系统识别准确率达97%。

采用机器学习中的降维和聚类算法可以增强预测模型的鲁棒性和学习能力。如陈英义等[55]使用主成分分析与LSTM的结合模型预测水产养殖水体溶解氧，试验表明该结合模型在评价指标上要优于传统的预测方法。郝玉莹等[56]将RF和LSTM模型结合形成RF-LSTM算法实现对地表水体水质的预测，并将RF-LSTM算法与LSTM、RF-BPNN和RF-RNN模型进行对比，最终实验预测结果显示RF-LSTM改进算法要优于其他的算法，具有极高的预测精度和较强的泛化能力。

通过现代精密仪器和技术以及人工检查所获得的数据都为风险预测提供了有效的信息输入，有利于更加全面地对预测对象进行评估监测。增加多源有效信息的输入是提升AI预测准确度的重要方法。

3.1.3 市场风险预测

市场经济体制下成本和出售价格的波动性会导致农户遭受损失。对市场风险的预测包括对价格和未来预期市场状态的预测。目前针对市场风险预测的研究主要是选择相关因子再对比使用多种预测模型进行预测。由于AI目前还存在可解释性不足的问题，因此在实际建模中往往是通过对比多种算法进行预测，最后选择其中表现最好的模型。

Jha和Sinha[57]使用ANN对大豆和油菜籽芥末的每月批发价格进行预测，在实证研究中证明了ANN模型的预测精度要优于线性模型。Paul等[58]用广义神经网络、支持向量机回归、RF和ARIMA算法对蔬菜价格进行预测，发现广义神经网络具有相对较好的预测精度。还有结合使用多种AI算法对未来农产品价格和状态进行预测的研究。Zhang等[59]使用29个变量刻画农产品价格特征，选用RF和SVM学习输入特征变量和候选模型间的潜在关系，采用最小冗余和最大相关法减少特征冗余以提高预测准确性，实验结果发现其所提出的预测模型优于所有候选模型。吕逸鹏和林旭东[60]使用SVM、BPNN和XGBoost算法对生猪价格进行涨跌分类，BPNN-XGBoost的组合模型在价格涨跌分类中的正确率达到94.59%。许钰林等[61]基于注意力机制对LSTM进行改进从而实现对玉米和大豆期货价格的预测，实验发现优化后的LSTM表现要优于ARIMA和支持向量回归模型，同时相比于单一的LSTM，加入注意力机制的LSTM表现也要更优，其中玉米和大豆期货预测结果的RMSE分别提升了0.6%和1.8%，证明了注意力机制可以提升模型的预测表现。

不同模型及算法有其各自的数据挖掘能力及适用范围。通过对比多种模型的预测准确度筛选出最优模型以及融合多种模型进行建模，这两种方法是具体实践中较为高效省事的模型性能提升方法。

3.2 时序关联数据及其适用算法应用

时序数据是指时间序列数据，是统一指标按时间顺序记录的数据列，而时序关联数据则是指前一个输入时间数据和后一个输入时间数据是有关联的。针对这样的时序关联数据，可以采用循环神经网络（Recurrent Nerual Network，RNN）和LSTM等模型进行预测建模任务。对于短时序关联数据可以采用循环神经网络进行建模，而当时间序列过长时会出现长期依赖问题，此时可以采用长短期记忆网络进行预测[62-64]。

Xing等[63]通过对比使用多种模型如多元线性回归、深度信念网络（Deep Belief Network，DBN）、使用多个受限玻尔兹曼机进行改进的LSTM-RNN（R-L-RNN）等，对苹果树的蒸腾作用进行预测，发现R-L-RNN获得了最准确的估计。对模型进行改进可以提高模型本身的数据挖掘能力。Venkatachalam等[64]基于14个天气特征，使用LSTM和转导长短期记忆网络进行天气预测，实验表明其所提出的T-LSTM模型要优于先前所提出的方法，还发现混合模型具有优越的泛化能力和更高的学习能力。Wang等[65]利用遥感数据进行产量估算，针对LSTM模型的特性，分析不同时间步长的时间序列对估计结果的影响，发现LSTM表现要优于传统的机器学习方法。Zhang等[66]利用卷积神经网络（Convolutional Neural Network，CNN）提取静态变量中的空间上下文特征和LSTM提取动态变量中的时间特征对土壤有机碳进行预测，采用RF模型作为参考比较模型，并证明CNN-LSTM混合模型预测的有效性。在实际预测中，通过多种模型混合的方法提高模型的泛化能力和预测能力。

另外，由于外界环境因素的干扰和自身变化的不规律性，使用AI算法对未来进行长期预测的难度要高于短期预测。针对此问题，当前有学者提出基于注意力机制的循环神经网络以挖掘时序数据中的信息。Liu等[67]提出了基于空间注意力、时间注意力、时空独立注意力、时间空间联合注意力的4种RNN方法，以捕获水产养殖中溶解氧短期时间序列和长期时间序列中的时空信息，再通过实验验证基于注意力机制的RNN在长短期预测中都要优于基准预测方法。

基于注意力机制的改进网络要优于传统的机器学习方法，原因在于前者可以挖掘时间序列中更多的时间和空间信息，进而增加模型所挖掘到的信息量，提高模型预测的准确性。从数据的角度出发，在建模预测时通过输入多维数据增加信息量，也可以提高模型预测的准确性。Celik等[68]将卫星图像数据和深度学习框架相结合，引入土壤质地和地形静态数据与气候动态数据，对土壤水分使用LSTM进行多维数据预测，均方根误差为0.046。Zhuang等[69]综合考虑农产品供需的关键因素如产量、消费、价格并结合自然、社会、经济因素，创建基于LSTM的分析工具。理论上来说，输入有效的信息越多，对未来风险进行预测的准确性也就越高，因此建模时不仅要关注对模型本身的改进和优化，在数据准备阶段收集有效数据对于提升模型表现也很重要。

3.3 图数据及其适用算法应用

在数据科学中，图数据被用来描述各种关系型数据。不同于语音、图像、文本等结构化数据，图数据属于复杂的非结构化数据，通过对一组对象（节点）及其关系（边）进行建模[70]。近年来，由于图的强大表达能力，利用机器学习分析图数据的研究也越来越受到关注，其应用侧重于节点分类、链接预测、聚类等学习任务[71-73]。可以采用图神经网络（Graph Nerual Network，GNN）、图卷积网络（Graph Convolutional Network，GCN）、图注意力网络（Graph Attention Network，GAN）、图递归网络（Graph Recurrent Network，GRN）进行图数据建模任务，学习不同节点之间丰富的关系信息。图神经网络在具有非独立因子的复杂系统中要优于传统机器学习方法，具有更加显著的优势。

Li等[74]以17个环境因子为输入变量，提出CoNet-GNN模型对水稻重金属浓度进行预测，预测精度显著优于基准机器学习模型。通过对不同类型数据之间的聚合信息提取，可以为模型训练提供更多的有效信息。Zeng等[75]针对现有滑坡敏感性评估存在着忽略环境异质性的问题和可能存在的不平衡正负样本问题，提出了一种受环境一致性约束的图神经网络，优化后的模型优于常见的机器学习方法，且在训练集小的情况下也能保持较高的预测精度。Kim等[76]将多类别图数据输入层次图注意力网络，实现对市场指数走势的预测。

当前针对于图结构数据的农业风险预测研究还不是很多，未来可以针对农业产业链的上下游关系和与农业相关的行业关系，对农业价格风险预测进一步深入研究。

3.4 对风险预测方法的评价

在农业风险预测中，不同数据类型的输入变量

有其适用的AI算法，而AI算法由于其强大的学习能力往往会出现过拟合现象。一般来说，建模所选择的AI算法模型要和所学习的模型参数个数尽量相同和参数向量尽量相近，否则当建模所选择模型的复杂度高于当前所学习的模型时，往往会导致模型对已知数据预测得很好，而对未知数据却预测得很差。通过模型选择可以避免过拟合问题并提高模型的预测能力。

在实际应用中，由于所学习的模型复杂度往往是不可知的或者难以评估的，研究者针对同一学习任务常采用多种模型进行对比学习，以MSE、RMSE、平均绝对误差（Mean Absolute Error，MAE）和R-squared等量化指标评价模型的学习能力从而实现对多种学习模型的选择。另外，还可以通过引入正则化项、降低模型参数数量、减少神经网络层数、数据增强、随机扰动等方法应对模型的过拟合问题。

4 在农业损害评估中的应用研究

当前自然灾害和病虫害对农业生产有着巨大的威胁，对农业受损情况进行准确而全面的评估对于农户减少损失和恢复生产意义重大。AI中的深度学习技术通过构建的神经网络模型可以对目标物的图像特征进行识别以判断物体类别或所处的状态，是当前损害评估的主流方法[77,78]。CNN是图像识别领域的代表算法之一，广泛应用于图像分类、图像分割和物体识别，典型的CNN由卷积层、池化层、全连接层组成，分别负责提取图像中的局部特征、大幅降低参数量以降维、输出结果。随着对CNN的改进，一些新的模型如AlexNet、VGG（Visual Geometry Group）、残差神经网络（Residual Neural Network，RestNet）、GoogLeNet、YOLO（You Only Look Once）、SSD（Single Shot MultiBox Detector）、全连接卷积神经网络（Fully Convolutional Networks，FCN）等也被应用到农业损害评估领域[79-82]，通过对受损对象的图像检测识别及图像分割，输出目标的受损程度和数量以及患病种类等结果，其应用过程如图4所示。深度学习技术对农业损害评估的应用类型包括图像检测识别和图像语义分割两大方面，图像检测识别是指识别图像里多个物体的类别和位置，位置通常用边缘框表示；图像语义分割则是将图片中的每个像素分类到对应的类别。

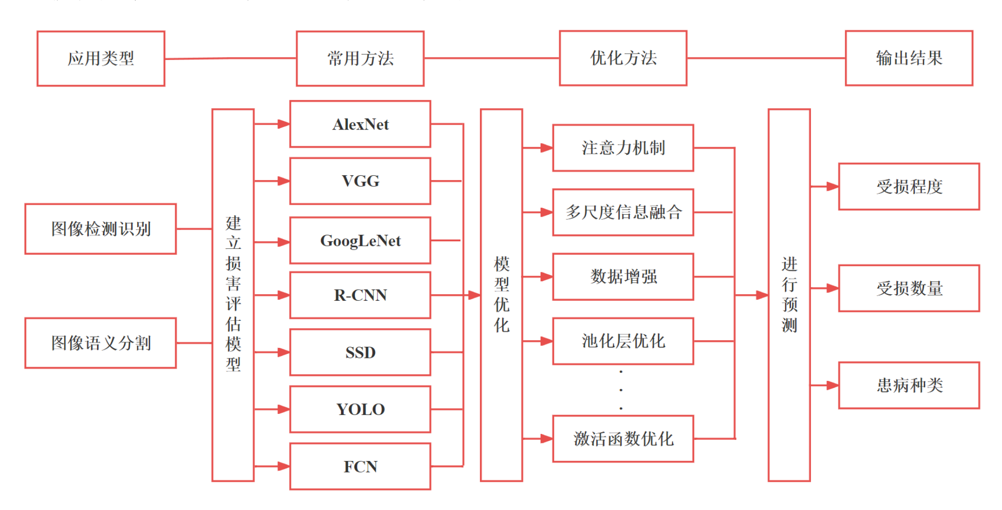


图4 基于AI的农业损害评估过程

Fig. 4 Agricultural damage assessment process based on artificial intelligence

4.1 图像检测识别

农业损害评估中的图像检测识别的应用先是识别损害农产品的状态，区分出正常农产品和受损农产品，在此基础之上，再对受损农产品进行计数，从而实现对生产状态的定量评估。

深度学习中的神经网络具有强大的特征自学习能力，擅长对图像中的物体特征进行提取从而实现图像识别的能力。Khattak等[83]使用CNN识别健康和患病状态的水果和叶子，测试准确率为94.55%。

Singh 等[84] 提出一种具有19个卷积层的CNN模型识别苹果叶疾病，准确率高达99.2%。Mirzazadeh等[85] 采用深度学习模型VGG16和ResNet50对受损油菜数据进行损害评估，其整体分类准确率分别为93.7%和98.2%。Yang 等[86] 利用CNN模型提取可见-近红外范围内的光谱特征来估算玉米幼苗的冷冻损伤，基于CNN的冷损伤检测结果与化学法检测结果的相关系数为0.8219，证实了使用CNN模型用于玉米冷害检测的可行性。

提高模型的特征提取能力和对比多种模型有助于增强模型的表现。Jiao 等[87] 将自适应特征融合入特征金字塔以提取更加丰富的害虫特征，其优化后的两阶段的基于区域的CNN在AgriPest21数据集上要明显优于其他图像识别模型，准确率达到77.0%。Bi 等[88] 从特征注意和多尺度特征融合学习出发，基于Swin Transformer提高对玉米种子的识别能力，实验验证其所提出的MFSwin Transformer模型分类精度最高，其平均精度、召回率和F_1值分别为96.53%、96.46%和96.47%。Lyu 等[89] 将空洞卷积和多尺度卷积相结合以提高特征提取能力，基于AlexNet神经网络设计出DMS-Robust AlexNet神经网络，最终其对玉米叶片病害的分类准确率达到98.62%。Sahu 和 J[90] 使用六种不同的深度学习架构，如优化的DenseNet121、CNN、ResNet50、MobileNet、VGG16 和 Inception-V3 对玉米叶病进行分类，发现使用超参数进行优化的DenseNet121分类性能最佳，准确率为99.35%，且与CNN和ResNet50相比，其参数更少，共计721万个。Gehlot 和 Saini[91] 使用 AlexNet、VGG-16、GoogleNet、DenseNet-121和ResNet-101对番茄叶片病害进行分类，实验发现DenseNet-121获得了最高的精度，平均验证准确率达到99.694%，并且与所有其他模型相比尺寸更小，只有89.6 MB。Hamidisepehr 等[92] 为了在恶劣天气事件发生之后及时检测评估玉米的受损区域，采用Faster R-CNN，YOLOv2和RetinaNet算法检测玉米受损区域，后两种算法表现出对玉米损伤较强的识别能力，RetinaNet和YOLOv2的最高平均精度分别为98.43%和97.0%。Shradha 等[93] 为了应对图像模型在独立测试数据上的性能显著下降问题，以番茄植物和目标斑病类型为例，采用分割的图像数据训练CNN模型，发现相比于使用完整图像数据训练相同的CNN模型，前者表现比后者提高了一倍以上，在独立数据上的性能达到98.6%。

通过迁移学习技术，可以有效缓解建模过程中存在的小样本问题和提高模型训练速度。万军杰等[94] 将迁移学习与GoogLeNet模型相结合，该优化模型对害虫的识别精度可达99.35%，危害程度分级精度可达92.78%，同时相比于其他常见模型，该模型验证精度提高了2.38%～11.44%，且收敛速度最快。Chen 等[95] 使用先前在ImageNet数据集中已经训练好的预训练模型VGGNet来初始化自己模型上的权重，其所提出的方法在公共数据集上实现了91.83%的验证精度，在复杂环境下的水稻病害图像分类预测的平均准确率也达到92%。周维等[96] 使用GhostNet结构替换YOLOv4中的主干特征提取网络以优化特征提取的能力，结合迁移学习与YOLOv4网络的训练技巧，将二者结合形成新的改进的YOLOv4-GhostNet算法对水稻病虫害进行识别，改进后的模型平均精确度达到79.38%。

提高图像识别模型的特征提取能力和鲁棒性是建模的主流方向。同时，为了更好地降低模型的使用门槛，设计更加轻量化的模型也是影响AI推广应用的重要因素。

4.2 图像语义分割

图像语义分割与图像检测识别的应用过程相同，但相比于图像识别，图像语义分割不管是在分割精度上，还是在模型训练量和数据预处理的工作量上，都要高于图像识别。

Reddy 和 Neeraja[97] 采用DenseNet对叶片损伤进行分类，再采用1D-CNN算法对图片进行语义分割，分割准确率达到97%。Yumang 等[98] 采用Mask R-CNN卷积神经网络模型实现对受损咖啡豆的分割，该模型准确率达到87.5%。Kumar 和 Kukreja[99] 使用Resnet-50用作Mask-RCNN模型的主干对小麦花叶病毒病进行分割，准确率达到88.19%。

分割物体常常容易与背景之间产生混淆是图像语义分割需要重点解决的问题。Das 和 Bais[100] 针

对作物叶子损坏的小圆形易与背景中白色石头产生混淆的问题，提出深度学习分割模型DeepVeg，准确率高于0.97，有效解决了受损油菜分割任务中的物体易混淆问题。Loyani等[101]提出了基于U-Net和Mask RCNN的卷积神经网络语义分割模型，在像素级别分割虫害对番茄的影响，其中Mask RCNN实现了85.67%的平均精度，U-Net模型的交集联合为78.60%以及Dice系数为82.86%。Zhang等[102]融合多光谱、植被指数和RGB信息，使用ResNeSt来提高提取特征的质量，引入注意力机制，提出了一种基于Unet++的RSPR-UNet++语义分割模型，用于分割遥感图像中的树皮甲虫和白杨潜叶虫感染区域，其准确率达到85.11%。Nasiri等[103]采用U-Net卷积神经网络架构作为深度编码器用于对甜菜、杂草和土壤的像素级别语义分割，结果发现使用具有适当分布和自定义损失函数的图像数据集可以提高分割精度，模型准确度高达0.9606以及IoU得分为0.8423。Memon等[104]提出元深度学习玉米叶病识别模型，并对比CNN、VGG16迁移学习、ResNet50三种模型，发现其所提出的模型准确率高达98.53%。

由于图像语义分割像素级别的分割精度，分割的目标物体常容易与环境背景产生混淆。针对此问题，在优化模型的结构基础之上，可以更多地引入分割目标相关领域的专业知识以增强对目标的特征学习。另外，像素级别的标注会耗费大量人力物力，降低数据预处理的成本对AI的推广应用至关重要。

4.3 对农业损害评估方法的评价

图像检测识别对目标进行识别的精度没有像素级别的语义分割算法高，但在生成训练数据的工作量上前者要少于后者，可根据实际应用的场景及成本预算对两种方法进行选择使用。农业生产环境复杂，应用场合多变，在进行模型训练时的场景往往是有限的，是否光照、光照强度、动植物不同生长时期的形态、遮挡以及牲畜之间的重叠等一系列复杂因素会降低模型的识别精度。由此可见，提升深度学习模型的特征提取能力和鲁棒性仍然是未来技术发展需要克服的重点和难点问题。

另外，当前在农业损害评估中，深度学习模型的训练仍然需要大量数据，针对于开源的同类别数据直接进行训练即可，而对于未开源的特定数据的标记往往需要耗费大量人力物力，尤其是图像中的语义分割更是需要进行像素级别的标注，如何减少学习任务中人力物力的投入对于AI的推广应用有着举足轻重的作用。同时，当前深度学习模型仍然属于端到端建模，以往通过对模型本身的优化可以提高模型的学习能力，之后可以更多地考虑引入外部知识，如将识别对象的专业特征融合入学习模型当中以提高模型的特征提取能力。

5　存在的主要问题及建议

从当前的研究进展可以看出，AI在农业风险管理的研究中有着优异的表现和诸多优势，尤其是在准确度和鲁棒性方面提升明显。但同时，也发现AI应用还存在一些缺陷和不足。AI要在农业风险管理中得到深入应用与推广，一些技术性问题还需要进一步探讨和解决。其中，两个主要的技术问题是模型性能提升问题和小样本问题。

5.1 模型性能提升问题

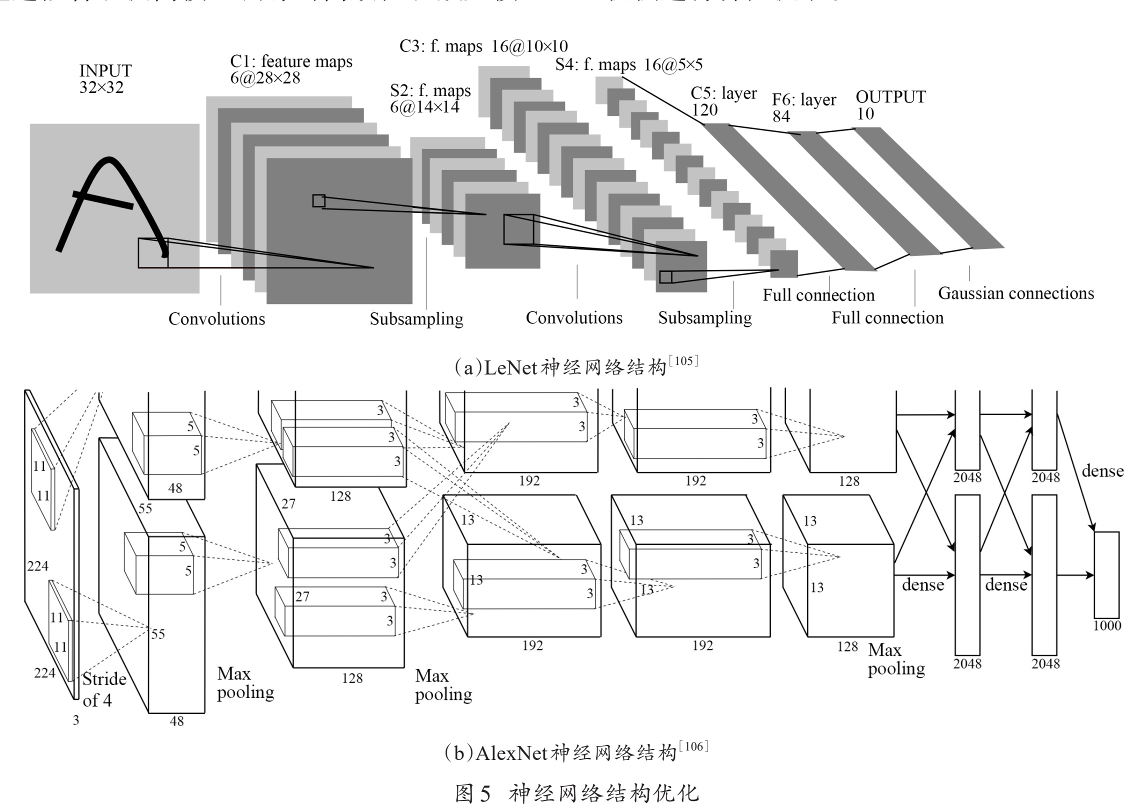
AI在农业风险管理研究中的模型性能提升一直是应用中的关键问题，模型性能提升主要包括特征提取能力提高、预测和识别精度提升和鲁棒性增强三大方面。尽管以往研究中通过调整模型自身参数能提升模型性能，但往往会遇到瓶颈，提升幅度并不理想。因此，为了更好地提升模型性能，可以尝试多种模型对比法、模型结合法和神经网络结构优化法等三种方法。

多种模型对比法是在不对已有模型进行改进的前提下，通过穷举法将候选模型集合中的所有模型和可能的对应参数用于进行任务建模，最终通过对比预测结果选取其中综合表现最好的模型和对应参数。具体实践中，如当学习任务为回归任务或者分类任务时，可以选择所有可能的回归或者分类算法进行建模，再根据评估指标选出其中的最优模型及参数。

模型结合法是指不同的模型具有不同的挖掘能力及适用的范围，通过“集百家之所长”的思想，

在组合不同模型的基础之上，再根据模型评价指标选出表现最好的组合模型和对应的参数，将不同模型之间组合起来往往可以得到较明显的优化效果。具体实践中，可以选择线性模型和非线性模型相结合、时间序列模型和空间结构模型相结合、降维聚类模型和回归分类模型相结合等。

神经网络结构的优化（图5）是指通过改变神经网络的部分结构如层数、非线性函数、卷积核大小和使用的池化类型等，以提高模型对特征的自动提取能力与对目标的识别精度、增强模型的鲁棒性以防止过拟合、提高模型训练的高效性和减少模型参数以实现轻量化应用等。LeNet神经网络最开始的提出是用于解决手写数字的识别问题，而随着识别任务难度的增大，原有的LeNet模型不再适用于复杂任务的识别，人们对LeNet进行改进提出了新的神经网络模型——AlexNet，该模型赢得了2012年的ImageNet竞赛冠军，向人们展现了其强大的图像识别能力。具体实践中，对神经网络结构的优化有很多方法，可以依据自身建模的任务需要对神经网络进行定制化构造，如为了学习被识别对象不同大小的特征，可以在神经网络中使用不同大小的卷积核进行特征提取。



(a)LeNet神经网络结构[105]

(b)AlexNet神经网络结构[106]

图5 神经网络结构优化

Fig. 5 Optimization of neural network structure

上述三种方法可依据实际使用人对AI的熟悉了解程度进行选择性采用以提升模型的性能。相对来说对比多种模型法是最容易实现的，只需根据哪些算法是属于回归还是分类类型，直接调用即可。模型结合法需要使用者对各种模型的应用领域及特点优势有较多的理解，通过不同模型的组合使用再进行调参，由于一定数量不同模型的组合以及调参时要使用到网格搜索法，使用模型结合法提升模型性能往往需要花费较多的时间在进行模型选择和参数训练上。神经网络结构优化法对使用者的深度学习理论基础以及代码能力要求较高，是三种性能提升方法中难度最大的，可以依据使用者自身具体情况进行选择。

5.2 小样本问题

数据就是AI的“石油”。进行机器学习算法训练时需要大量的数据集提供给模型本身去学习海量数据中所蕴含的信息和特征，挖掘出数据中线性和非线性的信息以进行模式识别。然而，在开展农业风险管理相关研究时发现，用于训练的数据样本往

往非常有限，尤其是针对多指标数据建模问题，常因为指标数据难收集和采集而出现小样本问题，让AI无法充分发挥效用。此外，针对AI所需的特定样本数据制作，例如病虫害病例照片的标签制作等，需要花费大量的人力和时间，且常常出现样本质量低、有效样本少的小样本问题。

为了解决小样本问题，并在不加大人力时间成本投入的前提下，可采用数据增广技术、迁移学习技术和生成对抗网络来处理。数据增广适合于数据集类型为图像的深度学习任务。所谓数据增广就是在原有图像数据集的基础之上，采用镜像、旋转、缩放、裁剪、平移、颜色抖动、调整对比度、随机擦除和高斯噪声等方法对图像数据进行处理以增加数据量[107, 108]。在计算机视觉领域，迁移学习技术在解决小样本问题中取得了很好的效果。生成对抗网络是一种无监督生成模型，学习过程是生成器和鉴别器两个神经网络之间的极大极小博弈，使用生成对抗网络扩展小规模数据集已经在AI领域得到了广泛的应用[109]。

在具体实践中，数据增广、迁移学习、生成对抗网络往往可以结合使用，数据增广和生成对抗网络强调对数据量的增加，从数据源头增加输入信息量以增加模型的鲁棒性，迁移学习偏重在相似识别模式下对已有神经网络结构和参数权重的调用来进行模型初始化，通常训练速度会更快且识别精度会更高。

6 总结与展望

本文阐述了AI在农业脆弱性评估、农业风险预测和农业损害评估三大方面的应用研究进展，总结认为AI农业风险管理应从以下方面展开。

（1）AI在农业脆弱性评估中的特征重要性评估缺乏科学有效的验证指标，且应用的方式导致无法比较多个AI算法之间的优劣，建议可采用主客观法进行评价，另外，未来可考虑将AI引入对农业脆弱性曲线的构建。

（2）在风险预测中，发现随着预测时间的增加，机器学习模型的预测能力往往会下降，过拟合问题是风险预测中的常见问题。且目前研究针对图数据空间信息的挖掘还较少，针对农业产业链的上下游关系和与农业相关的行业关系，未来可以更多地应用图神经网络对农业价格风险预测进一步深入研究。

（3）在损害评估中，提高模型的特征提取能力和鲁棒性是建模的主流方向，未来可以更多地引入评估目标相关领域的专业知识以增强对目标的特征学习，另外模型训练需要对大量图像数据进行标注，耗时耗力，对小样本数据进行增广也是未来研究的重点内容。

AI由于其强大的自学习能力在很多领域得到了广泛应用，然而其存在的“黑箱”可解释性差、数据标注成本大和算力要求高等问题也不可避免地限制了它的进一步发展与推广。增强AI的可解释性、提高模型训练的效率、提升算法模型的学习能力和减少人工标注数据的成本等问题有待进一步地深入研究。如今，中国的农业正在朝着智慧农业转型，伴随着AI、物联网、大数据和云计算等方面技术的提升与深入应用，可以预见，未来的农业风险管理将会愈发高效、精准和智能。

利益冲突声明：本研究不存在研究者以及与公开研究成果有关的利益冲突。

参考文献：

[1] BENAMI E, JIN Z N, CARTER M R, et al. Uniting remote sensing, crop modelling and economics for agricultural risk management[J]. Nature reviews earth & environment, 2021, 2(2): 140-159.
[2] 赵思健, 张峭. 东北三省农作物洪涝时空风险评估[J]. 灾害学, 2013, 28(3): 54-60.
ZHAO S J, ZHANG Q. Spatial-temporal risk assessment of crops caused by flood in the three northeastern provinces of China[J]. Journal of catastrophology, 2013, 28(3): 54-60.
[3] CHEN W, JIANG Y. Application of Markov Model-Based IoT in Agricultural Insurance and Risk Management[J]. Mobile information systems, 2021, 2021: 1-8.
[4] WANG C L, GAO Y W, AZIZ A, et al. Agricultural disaster risk management and capability assessment using big data analytics[J]. Big data, 2022, 10(3): 246-261.
[5] 刘学文. 中国农业风险管理研究——基于完善农业风险管理体系的视角[D]. 成都: 西南财经大学, 2014.
LIU X W. The analysis on agriculture's risk management in China— From the perspective of improving the agriculture's risk management system[D]. Chengdu: Southwestern University of Finance and Economics, 2014.
[6] GHAFFARIAN S, VAN DER VOORT M, VALENTE J,

et al. Machine learning-based farm risk management: A systematic mapping review[J]. Computers and electronics in agriculture, 2022, 192: ID 106631.
[7] 张峭, 王克, 汪必旺, 等. 农业风险综合管理: 一个理论框架[J]. 农业展望, 2016, 12(3): 59-65.
ZHANG Q, WANG K, WANG B W, et al. Integrated risk management in agriculture: A theoretical framework[J]. Agricultural outlook, 2016, 12(3): 59-65.
[8] 别得进, 朱秀芳, 赵安周, 等. 农业旱灾脆弱性研究综述[J]. 北京师范大学学报(自然科学版), 2015, 51(S1): 62-69.
BIE D J, ZHU X F, ZHAO A Z, et al. Assessment of agricultural drought vulnerability: A review[J]. Journal of Beijing normal university (natural science), 2015, 51(S1): 62-69.
[9] PARKER L, BOURGOIN C, MARTINEZ-VALLE A, et al. Vulnerability of the agricultural sector to climate change: The development of a pan-tropical Climate Risk Vulnerability Assessment to inform sub-national decision making[J]. PLoS One, 2019, 14(3): ID e0213641.
[10] PATHAK T, MASKEY M, DAHLBERG J, et al. Climate change trends and impacts on California agriculture: A detailed review[J]. Agronomy, 2018, 8(3): ID 25.
[11] YANG W, XU K, LIAN J, et al. Integrated flood vulnerability assessment approach based on TOPSIS and Shannon entropy methods[J]. Ecological indicators, 2018, 89: 269-280.
[12] 谢家智, 车四方, 林涌. 农业旱灾风险管理脆弱性评价及驱动因素分析[J]. 西南大学学报(社会科学版), 2017, 43(3): 43-53, 189.
XIE J Z, CHE S F, LIN Y. Vulnerability assessment and the driving force in the management of agricultural drought hazard[J]. Journal of southwest university (social sciences edition), 2017, 43(3): 43-53, 189.
[13] HANADÉ HOUMMA I, MANSOURI LEL, GADAL S, et al. Modelling agricultural drought: A review of latest advances in big data technologies[J]. Geomatics, natural hazards and risk, 2022, 13(1): 2737-2776.
[14] TAMAGNO S, EAGLE A J, MCLELLAN E L, et al. Predicting nitrate leaching loss in temperate rainfed cereal crops: Relative importance of management and environmental drivers[J]. Environmental research Letters, 2022, 17(6): ID 064043.
[15] ABDALLAH EBEN, GRATI R, BOUKADI K. A machine learning-based approach for smart agriculture via stacking-based ensemble learning and feature selection methods[C]// 2022 18th International Conference on Intelligent Environments (IE). Piscataway, NJ, USA: IEEE, 2022: 1-8.
[16] LI Y, GONG S Y, ZHANG Z R, et al. Vulnerability evaluation of rainstorm disaster based on ESA conceptual framework: A case study of Liaoning province, China[J]. Sustainable cities and society, 2021, 64: ID 102540.
[17] DENG X Y, WANG G Q, YAN H F, et al. Spatial‐temporal pattern and influencing factors of drought impacts on agriculture in China[J]. Frontiers in environmental science, 2022, 10: ID 820615.
[18] KINNUNEN P, HEINO M, SANDSTRÖM V, et al. Crop yield loss risk is modulated by anthropogenic factors[J]. Earth's future, 2022, 10(9): ID e2021EF002420.
[19] 孙鹏, 刘果锞, 梁媛媛, 等. 基于机器学习算法的安徽省农业旱灾风险动态评估[J]. 水利水电技术(中英文), 2022, 53(5): 22-35.
SUN P, LIU G N, LIANG Y Y, et al. Machine learning algorithm-based dynamic assessment of agricultural drought dangerousness in Anhui province[J]. Water resources and hydropower engineering, 2022, 53(5): 22-35.
[20] SAMUEL J, RAO C A R, RAJU B M K, et al. Assessing the impact of climate resilient technologies in minimizing drought impacts on farm incomes in drylands[J]. Sustainability, 2021, 14(1): ID 382.
[21] 刘伟, 徐洁, 黎洁. 陕南易地扶贫搬迁农户生计脆弱性研究[J]. 资源科学, 2018, 40(10): 2002-2014.
LIU W, XU J, LI J. Livelihood vulnerability of rural households under poverty alleviation relocation in southern Shaanxi, China[J]. Resources science, 2018, 40(10): 2002-2014.
[22] MELKETO T, SCHMIDT M, BONATTI M, et al. Determinants of pastoral household resilience to food insecurity in a far region, northeast Ethiopia[J]. Journal of arid environments, 2021, 188: ID 104454.
[23] 和月月, 周常春. 贫困地区农户生计脆弱性评价及影响因素分析[J]. 统计与决策, 2020, 36(19): 70-74.
HE Y Y, ZHOU C C. Vulnerability evaluation and influencing factors analysis of farmers' livelihood in poverty-stricken areas[J]. Statistics & decision, 2020, 36(19): 70-74.
[24] SAHA T K, PAL S. Exploring physical wetland vulnerability of Atreyee River Basin in India and Bangladesh using logistic regression and fuzzy logic approaches[J]. Ecological indicators, 2019, 98: 251-265.
[25] ROY P, PAL S C, CHAKRABORTTY R, et al. Climate change and groundwater overdraft impacts on agricultural drought in India: Vulnerability assessment, food security measures and policy recommendation[J]. Science of the total environment, 2022, 849: ID 157850.
[26] 张帅, 董会忠, 曾文霞. 土地生态系统脆弱性时空演化特征及影响因素——以黄河三角洲高效生态经济区为例[J]. 中国环境科学, 2019, 39(4): 1696-1704.
ZHANG S, DONG H Z, ZENG W X. The time-space evolution characteristics of the vulnerability of land ecosystems and influencing factors: A case study of the Yellow River Delta Efficiency Eco-economic Zone[J]. China environmental science, 2019, 39(4): 1696-1704.
[27] SAHA S, KUNDU B, SAHA A, et al. Manifesting deep learning algorithms for developing drought vulnerability index in monsoon climate dominant region of West Bengal, India[J]. Theoretical and applied climatology, 2023, 151(1): 891-913.
[28] 苏芳, 李景坤, 许韶华. 基于BP神经网络的农户生计风

险评价模型[J]. 冰川冻土, 2017, 39(6): 1381-1390.
SU F, LI J K, XU S H. An assessment model of farmer livelihood risk based on BP neural network[J]. Journal of glaciology and geocryology, 2017, 39(6): 1381-1390.
[29] KIRASICH K, SMITH T, SADLER B. Random forest vs logistic regression: Binary classification for heterogeneous datasets[J]. SMU Data science review, 2018, 1(3): ID 9.
[30] FUNG K F, HUANG Y F, KOO C H, et al. Improved SVR machine learning models for agricultural drought prediction at downstream of Langat River Basin, Malaysia[J]. Journal of water and climate change, 2020, 11(4): 1383-1398.
[31] SUTANTO S J, VAN DER WEERT M, WANDERS N, et al. Moving from drought hazard to impact forecasts[J]. Nature communications, 2019, 10(1): 1-7.
[32] 李航. 统计学习方法[M]. 北京: 清华大学出版社, 2012.
LI H. Statistical learning method[M]. Beijing: Tsinghua University Press, 2012.
[33] VAN KLOMPENBURG T, KASSAHUN A, CATAL C. Crop yield prediction using machine learning: A systematic literature review[J]. Computers and electronics in agriculture, 2020, 177: ID 105709.
[34] HE L L, FANG W T, ZHAO G N, et al. Fruit yield prediction and estimation in orchards: A state-of-the-art comprehensive review for both direct and indirect methods[J]. Computers and electronics in agriculture, 2022, 195: ID 106812.
[35] PRODHAN F A, ZHANG J H, HASAN S S, et al. A review of machine learning methods for drought hazard monitoring and forecasting: Current research trends, challenges, and future research directions[J]. Environmental modelling & software, 2022, 149: ID 105327.
[36] DOMINGUES T, BRANDÃO T, FERREIRA J C. Machine learning for detection and prediction of crop diseases and pests: A comprehensive survey[J]. Agriculture, 2022, 12(9): ID 1350.
[37] RADOČAJ D, JURIŠIĆ M. GIS-based cropland suitability prediction using machine learning: A novel approach to sustainable agricultural production[J]. Agronomy, 2022, 12(9): ID 2210.
[38] ZOUNEMAT-KERMANI M, BATELAAN O, FADAEE M, et al. Ensemble machine learning paradigms in hydrology: A review[J]. Journal of hydrology, 2021, 598: ID 126266.
[39] PEI F S, LI X, LIU X P, et al. Assessing the impacts of droughts on net primary productivity in China[J]. Journal of environmental management, 2013, 114: 362-371.
[40] HA T V, HUTH J, BACHOFER F, et al. A review of earth observation-based drought studies in southeast Asia[J]. Remote sensing, 2022, 14(15): ID 3763.
[41] PRODHAN F A, ZHANG J H, YAO F M, et al. Deep learning for monitoring agricultural drought in South Asia using remote sensing data[J]. Remote sensing, 2021, 13(9): ID 1715.
[42] PARK S, SEO E, KANG D, et al. Prediction ofdrought on pentad scale using remote sensing data and MJO index through random forest over East Asia[J]. Remote sensing, 2018, 10(11): ID 1811.
[43] ZHANG Q, SHI R, SINGH V P, et al. Droughts across China: Drought factors, prediction and impacts[J]. Science of the total environment, 2022, 803: ID 150018.
[44] LI J, WANG Z L, WU X S, et al. Robust meteorological drought prediction using antecedent SST fluctuations and machine learning[J]. Water resources research, 2021, 57(8): ID e2020WR029413.
[45] 张建海, 张棋, 许德合, 等. ARIMA-LSTM组合模型在基于SPI干旱预测中的应用——以青海省为例[J]. 干旱区地理, 2020, 43(4): 1004-1013.
ZHANG J H, ZHANG Q, XU D H, et al. Application of a combined *ARIMA*-LSTM model based on SPI for the forecast of drought: A case study in Qinghai province[J]. Arid land geography, 2020, 43(4): 1004-1013.
[46] WANG Y, HONG H Y, CHEN W, et al. Flood susceptibility mapping in Dingnan County (China) using adaptive neuro-fuzzy inference system with biogeography based optimization and imperialistic competitive algorithm[J]. Journal of environmental management, 2019, 247: 712-729.
[47] VENKATESAN E, MAHINDRAKAR A B. Forecasting floods using extreme gradient boosting: A new approach[J]. International journal of civil engineering and technology, 2019, 10(2): 1336-1346.
[48] MIRZAEI S, VAFAKHAH M, PRADHAN B, et al. Flood susceptibility assessment using extreme gradient boosting (EGB), Iran[J]. Earth science informatics, 2021, 14(1): 51-67.
[49] TABBUSSUM R, DAR A Q. Performance evaluation of artificial intelligence paradigms—Artificial neural networks, fuzzy logic, and adaptive neuro-fuzzy inference system for flood prediction[J]. Environmental science and pollution research, 2021, 28(20): 25265-25282.
[50] ZHANG K, NIU J F, LI X, et al. Comparison of artificial intelligence flood forecasting models in China's semi-arid and semi-humid regions[J]. Water resources protection, 2021, 37(1): 28-35.
[51] EBRAHIMI M, MOHAMMADI-DEHCHESHMEH M, EBRAHIMIE E, et al. Comprehensive analysis of machine learning models for prediction of sub-clinical mastitis: Deep learning and Gradient-boosted trees outperform other models[J]. Computers in biology and medicine, 2019, 114: ID 103456.
[52] TEIXEIRA V A, LANA A M Q, BRESOLIN T, et al. Using rumination and activity data for early detection of anaplasmosis disease in dairy heifer calves[J]. Journal of dairy science, 2022, 105(5): 4421-4433.
[53] CASELLA E, CANTOR M C, SILVESTRI S, et al. Cost-aware inference of bovine respiratory disease in calves using precision livestock technology[C]// 2022 18th International Conference on Distributed Computing in Sensor

Systems(DCOSS). Piscataway, NJ, USA: IEEE, 2022: 109-116.

[54] AHMED G, MALICK R A S, AKHUNZADA A, et al. An approach towards IoT-based predictive service for early detection of diseases in poultry chickens[J]. Sustainability, 2021, 13(23): ID 13396.

[55] 陈英义, 程倩倩, 方晓敏, 等. 主成分分析和长短时记忆神经网络预测水产养殖水体溶解氧[J]. 农业工程学报, 2018, 34(17): 183-191.
CHEN Y Y, CHENG Q Q, FANG X M, et al. Principal component analysis and long short-term memory neural network for predicting dissolved oxygen in water for aquaculture[J]. Transactions of the Chinese society of agricultural engineering, 2018, 34(17): 183-191.

[56] 郝玉莹, 赵林, 孙同, 等. 基于RF-LSTM的地表水体水质预测[J]. 水资源与水工程学报, 2021, 32(6): 41-48.
HAO Y Y, ZHAO L, SUN T, et al. Surface water quality prediction based on RF-LSTM[J]. Journal of water resources and water engineering, 2021, 32(6): 41-48.

[57] JHA G, SINHA K. Agricultural price forecasting using neural network model: An innovative information delivery system[J]. Agricultural economics research review, 2013, 26(347-2016-17087): 229-239.

[58] PAUL R K, YEASIN M, KUMAR P, et al. Machine learning techniques for forecasting agricultural prices: A case of brinjal in *Odisha*, India[J]. PLoS One, 2022, 17(7): ID e0270553.

[59] ZHANG D B, CHEN S Y, LING L W, et al. Forecasting agricultural commodity prices using model selection framework with time series features and forecast horizons[J]. IEEE access, 2020, 8: 28197-28209.

[60] 吕逸鹏, 林旭东. 基于分类模型的生猪价格预测[J]. 中国畜牧杂志, 2020, 56(12): 215-219.
LYU Y P, LIN X D. Pork price prediction based on classification model[J]. Chinese journal of animal science, 2020, 56(12): 215-219.

[61] 许钰林, 康孟珍, 王秀娟, 等. 基于深度学习的玉米和大豆期货价格智能预测[J]. 智慧农业(中英文), 2022, 4(4): 156-163.
XU Y L, KANG M Z, WANG X J, et al. Corn and soybean futures price intelligent forecasting based on deep learning[J]. Smart agriculture, 2022, 4(4): 156-163.

[62] WONGCHAI A, JENJETI D R, PRIYADARSINI A I, et al. Farm monitoring and disease prediction by classification based on deep learning architectures in sustainable agriculture[J]. Ecological modelling, 2022, 474: ID 110167.

[63] XING L W, CUI N B, LIU C W, et al. Estimation of daily apple tree transpiration in the Loess Plateau region of China using deep learning models[J]. Agricultural water management, 2022, 273: ID 107889.

[64] VENKATACHALAM K, TROJOVSKÝ P, PAMUCAR D, et al. DWFH: An improved data-driven deep weather forecasting hybrid model using Transductive Long Short Term Memory (*T*-LSTM)[J]. Expert systems with applications, 2023, 213: ID 119270.

[65] WANG J A, SI H P, GAO Z, et al. Winter wheat yield prediction using an LSTM model from MODIS LAI products[J]. Agriculture, 2022, 12(10): ID 1707.

[66] ZHANG L, CAI Y Y, HUANG H L, et al. A CNN-LSTM model for soil organic carbon content prediction with long time series of MODIS-based phenological variables[J]. Remote sensing, 2022, 14(18): ID 4441.

[67] LIU Y Q, ZHANG Q, SONG L H, et al. Attention-based recurrent neural networks for accurate short-term and long-term dissolved oxygen prediction[J]. Computers and electronics in agriculture, 2019, 165: ID 104964.

[68] CELIK M F, ISIK M S, YUZUGULLU O, et al. Soil moisture prediction from remote sensing images coupled with climate, soil texture and topography via deep learning[J]. Remote sensing, 2022, 14(21): ID 5584.

[69] ZHUANG J Y, XU S W, LI G Q, et al. Intelligentdecision method of multi-agricultural commodity model based on machine learning[J]. International journal of pattern recognition and artificial intelligence, 2022, 36(8): ID 2251003.

[70] 刘忠雨, 李彦霖, 周洋. 深入浅出图神经网络: GNN 原理解析[M]. 北京: 机械工业出版社, 2020.
LIU Z Y, LI Y L, ZHOU Y. Learning graph neural network[M]. Beijing: China Machine Press, 2020.

[71] ZHOU J, CUI G Q, HU S D, et al. Graph neural networks: A review of methods and applications[J]. AI open, 2020, 1: 57-81.

[72] ZHOU Y, ZHENG H X, HUANG X, et al. Graph neural networks: Taxonomy, advances, and trends[J]. ACM transactions on intelligent systems and technology, 2022, 13 (1): ID 15.

[73] LACHAUD G, CONDE-CESPEDES P, TROCAN M. Mathematical expressiveness of graph neural networks[J]. Mathematics, 2022, 10(24): ID 4770.

[74] LI P P, HAO H J, ZHANG Z, et al. A field study to estimate heavy metal concentrations in a soil-rice system: Application of graph neural networks[J]. Science of the total environment, 2022, 832: ID 155099.

[75] ZENG H W, ZHU Q, DING Y L, et al. Graph neural networks with constraints of environmental consistency for landslide susceptibility evaluation[J]. International journal of geographical information science, 2022, 36(11): 2270-2295.

[76] KIM R, SO C H, JEONG M, et al. Hats: A hierarchical graph attention network for stock movement prediction[J/OL]. arXiv:190807999, 2019.

[77] MAMAT N, OTHMAN M F, ABDOULGHAFOR R, et al. Advancedtechnology in agriculture industry by implementing image annotation technique and deep learning approach: A review[J]. Agriculture, 2022, 12(7): ID 1033.

[78] ADI M, SINGH A K, REDDY A H, et al. An overview on plant disease detection algorithm using deep learning[C]// 2021 2nd International Conference on Intelligent Engineering and Management (ICIEM). Piscataway, NJ, USA: IEEE, 2021: 305-309.

[79] MAHESWARI P, RAJA P, APOLO-APOLO O E, et al. In-

telligent fruit yield estimation for orchards using deep learning based semantic segmentation techniques-a review[J]. Frontiers in plant science, 2021, 12: ID 684328.

[80] QIN Q, HU X J. The application of attention mechanism in semantic image segmentation[C]// 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). Piscataway, NJ, USA: IEEE, 2020: 1573-1580.

[81] JIANG B D, AN X Y, XU S F, et al. Intelligentimage semantic segmentation: A review through deep learning techniques for remote sensing image analysis[J]. Journal of the Indian society of remote sensing, 2022: 1-14.

[82] PUNITHAVATHI R, DELPHIN CAROLINA RANI A, SUGHASHINI K R, et al. Computer vision and deep learning-enabled weed detection model for precision agriculture[J]. Computer systems science and engineering, 2023, 44(3): 2759-2774.

[83] KHATTAK A, ASGHAR M U, BATOOL U, et al. Automatic detection of *Citrus* fruit and leaves diseases using deep neural network model[J]. IEEE access, 2021, 9: 112942-112954.

[84] SINGH S, GUPTA I, GUPTA S, et al. Deep learning based automated detection of diseases from apple leaf images[J]. CMC-Computers, Materials & Continua, 2022, 71 (1): 1849-1866.

[85] MIRZAZADEH A, AZIZI A, ABBASPOUR-GILANDEH Y, et al. A novel technique for classifying bird damage to rapeseed plants based on a deep learning algorithm[J]. Agronomy, 2021, 11(11): ID 2364.

[86] YANG W, YANG C, HAO Z Y, et al. Diagnosis of plant cold damage based on hyperspectral imaging and convolutional neural network[J]. IEEE Access, 2019, 7: 118239-118248.

[87] JIAO L, XIE C J, CHEN P, et al. Adaptive feature fusion pyramid network for multi-classes agricultural pest detection[J]. Computers and electronics in agriculture, 2022, 195: ID 106827.

[88] BI C G, HU N, ZOU Y Q, et al. Development of deep learning methodology for maize seed variety recognition based on improved swin transformer[J]. Agronomy, 2022, 12(8): ID 1843.

[89] LYU M J, ZHOU G X, HE M F, et al. Maize leaf disease identification based on feature enhancement and DMS-robust alexnet[J]. IEEE access, 2020, 8: 57952-57966.

[90] SAHU S, J A. Maize Plant Disease classification using optimized DenseNet121[C]// 2022 OITS International Conference on Information Technology (OCIT). Piscataway, NJ, USA: IEEE, 2022: 1-6.

[91] GEHLOT M, SAINI M L. Analysis of different CNN architectures for tomato leaf disease classification[C]// 2020 5th IEEE International Conference on Recent Advances and Innovations in Engineering (ICRAIE). Piscataway, NJ, USA: IEEE, 2021: 1-6.

[92] HAMIDISEPEHR A, MIRNEZAMI S V, WARD J K. Comparison of object detection methods for corn damage assessment using deep learning[J]. Transactions of the ASABE, 2020, 63(6): 1969-1980.

[93] SHARMA P, BERWAL Y P S, GHAI W. Performance analysis of deep learning CNN models for disease detection in plants using image segmentation[J]. Information processing in agriculture, 2020, 7(4): 566-574.

[94] 万军杰, 祁力钧, 卢中奥, 等. 基于迁移学习的GoogLeNet果园病虫害识别与分级[J]. 中国农业大学学报, 2021, 26(11): 209-221.
WAN J J, QI L J, LU Z A, et al. Recognition and grading of diseases and pests in orchard by GoogLeNet based on Transfer Learning[J]. Journal of China agricultural university, 2021, 26(11): 209-221.

[95] CHEN J D, CHEN J X, ZHANG D F, et al. Using deep transfer learning for image-based plant disease identification[J]. Computers and electronics in agriculture, 2020, 173: ID 105393.

[96] 周维, 牛永真, 王亚炜, 等. 基于改进的YOLOv4-GhostNet水稻病虫害识别方法[J]. 江苏农业学报, 2022, 38 (3): 685-695.
ZHOU W, NIU Y Z, WANG Y W, et al. Rice pests and diseases identification method based on improved YOLOv4-GhostNet[J]. Jiangsu journal of agricultural sciences, 2022, 38(3): 685-695.

[97] REDDY B S, NEERAJA S. Plant leaf disease classification and damage detection system using deep learning models[J]. Multimedia tools and applications, 2022, 81 (17): 24021-24040.

[98] YUMANG A N, CHLOE M STA JUANA M, DILOY R L C. Detection and classification of defective fresh excelsa beans using mask R-CNN algorithm[C]// 2022 14th International Conference on Computer and Automation Engineering (ICCAE). Piscataway, NJ, USA: IEEE, 2022: 97-102.

[99] KUMAR D, KUKREJA V. Image-based wheat mosaic virus detection with mask-RCNN model[C]// 2022 International Conference on Decision Aid Sciences and Applications (DASA). Piscataway, NJ, USA: IEEE, 2022: 178-182.

[100] DAS M, BAIS A. DeepVeg: Deep learning model for segmentation of weed, canola, and canola flea beetle damage[J]. IEEE access, 2021, 9: 119367-119380.

[101] LOYANI L K, BRADSHAW K, MACHUVE D. Segmentation of *Tuta absoluta*'s damage on tomato plants: A computer vision approach[J]. Applied artificial intelligence, 2021, 35(14): 1107-1127.

[102] ZHANG J Z, CONG S J, ZHANG G, et al. Detecting pest-infested forest damage through multispectral satellite imagery and improved UNet+ [J]. Sensors (basel, Switzerland), 2022, 22(19): ID 7440.

[103] NASIRI A, OMID M, TAHERI-GARAVAND A, et al. Deep learning-based precision agriculture through weed recognition in sugar beet fields[J]. Sustainable computing: Informatics and systems, 2022, 35: ID 100759.

[104] MEMON M S, KUMAR P, IQBAL R. Metadeep learn

leaf disease identification model for cotton crop[J]. Computers, 2022, 11(7): 102.
[105] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
[106] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
[107] 马岽奡, 唐娉, 赵理君, 等. 深度学习图像数据增广方法研究综述[J]. 中国图象图形学报, 2021, 26(3): 487-502.
MA D A, TANG P, ZHAO L J, et al. Review of data augmentation for image in deep learning[J]. Journal of image and graphics, 2021, 26(3): 487-502.
[108] ZHUANG F Z, QI Z Y, DUAN K Y, et al. A comprehensive survey on transfer learning[J]. Proceedings of the IEEE, 2021, 109(1): 43-76.
[109] ZHANG L, NIE Q, JI H Y, et al. Hyperspectral imaging combined with generative adversarial network (GAN)-based data augmentation to identify haploid maize kernels[J]. Journal of food composition and analysis, 2022, 106: ID 104346.

Research Application of Artificial Intelligence in Agricultural Risk Management: A Review

GUI Zechun, ZHAO Sijian*

（*Agricultural Information Institute*, *Chinese Academy of Agricultural Sciences*, *Beijing* 100081, *China*）

Abstract: Agriculture is a basic industry deeply related to the national economy and people's livelihood, while it is also a weak industry. There are some problems with traditional agricultural risk management research methods, such as insufficient mining of nonlinear information, low accuracy and poor robustness. Artificial intelligence(AI) has powerful functions such as strong nonlinear fitting, end-to-end modeling, feature self-learning based on big data, which can solve the above problems well. The research progress of artificial intelligence technology in agricultural vulnerability assessment, agricultural risk prediction and agricultural damage assessment were first analyzed in this paper, and the following conclusions were obtained: 1. The feature importance assessment of AI in agricultural vulnerability assessment lacks scientific and effective verification indicators, and the application method makes it impossible to compare the advantages and disadvantages of multiple AI models. Therefore, it is suggested to use subjective and objective methods for evaluation; 2. In risk prediction, it is found that with the increase of prediction time, the prediction ability of machine learning model tends to decline. Overfitting is a common problem in risk prediction, and there are few researches on the mining of spatial information of graph data; 3. Complex agricultural production environment and varied application scenarios are important factors affecting the accuracy of damage assessment. Improving the feature extraction ability and robustness of deep learning models is a key and difficult issue to be overcome in future technological development. Then, in view of the performance improvement problem and small sample problem existing in the application process of AI technology, corresponding solutions were put forward. For the performance improvement problem, according to the user's familiarity with artificial intelligence, a variety of model comparison method, model group method and neural network structure optimization method can be used respectively to improve the performance of the model; For the problem of small samples, data augmentation, GAN (Generative Adversarial Network) and transfer learning can often be combined to increase the amount of input data of the model, enhance the robustness of the model, accelerate the training speed of the model and improve the accuracy of model recognition. Finally, the applications of AI in agricultural risk management were prospected: In the future, AI algorithm could be considered in the construction of agricultural vulnerability curve; In view of the relationship between upstream and downstream of agricultural industry chain and agriculture-related industries, the graph neural network can be used more in the future to further study the agricultural price risk prediction; In the modeling process of future damage assessment, more professional knowledge related to the assessment target can be introduced to enhance the feature learning of the target, and expanding the small sample data is also the key subject of future research.

Key words: agricultural risk management; artificial intelligence; vulnerability assessment; risk prediction; damage assessment